



Predição do afilamento de *Tectona grandis* L.f. na Amazônia Oriental

Lucas Sérgio de Sousa LOPES ^{*1}, Daniela PAULETTO ², Cleidiane Nunes dos SANTOS ¹,
Nievis Adelina Corrêa de Miranda ANJOS ³, Rafael RODE ², Ádria Fernandes da SILVA ²,
Roberta Souza MENDES ³, Gabriel Brito COSTA ²

¹ Universidade Federal Rural da Amazônia, Capitão Poço, PA, Brasil.

² Instituto de Biodiversidade e Florestas, Universidade Federal do Oeste do Pará, Santarém, PA, Brasil.

³ Instituto de Ciências Agrárias, Universidade Federal Rural da Amazônia, Belém, PA, Brasil.

*E-mail: lucas.sousa@ufra.edu.br

**Artigo selecionado no II Simpósio de Engenharia Florestal do Oeste do Pará - II SEFOP – UFOPA, 2025.

Submetido: 14/01/2026; Aceito: 19/02/2026; Publicado: xx/02/2026.

RESUMO: O afilamento do fuste constitui uma variável essencial para o manejo e o aproveitamento racional da madeira, permitindo estimar os diâmetros ao longo do fuste e determinar os respectivos sortimentos. Este estudo teve como objetivo comparar o desempenho de diferentes abordagens estatísticas e de aprendizado de máquina na predição do afilamento de *Tectona grandis* L.f. em Santarém, Pará. Foram amostradas 30 árvores, totalizando 261 observações de diâmetro (di). Utilizaram-se como variáveis preditoras o diâmetro a 1,3 m de altura (dap), a altura comercial (hc), a altura total (ht) e a altura relativa (hi). As abordagens testadas foram o modelo de Kozak, a árvore de regressão (CART), o Random Forest (RF), a Support Vector Machine (SVM) e a Gradient Boosting Machine (GBM). A avaliação do desempenho foi realizada por meio da raiz do erro quadrático médio (RMSE), erro médio absoluto (MAE) e coeficiente de correlação linear ($r_{\hat{y}y}$) para as etapas de treinamento e generalização. O algoritmo GBM apresentou os melhores resultados, com $r_{\hat{y}y} > 0,99$ e RMSE de 0,45 cm, seguido pelo RF. O modelo de Kozak e a árvore de regressão apresentaram maior dispersão dos erros e menor capacidade de generalização. A análise dos erros relativos indicou que o GBM produziu predições mais precisas, sem viés sistemático. Conclui-se que as abordagens baseadas em aprendizado de máquina, especialmente o GBM, apresentam maior eficiência para modelar o afilamento do fuste de teca, superando modelos convencionais de regressão quanto à exatidão e à precisão preditiva.

Palavras-chave: aprendizado de máquina; inteligência artificial; mensuração florestal.

Predicting taper in *Tectona grandis* L.f. in the Eastern Amazon

ABSTRACT: Stem taper is an essential variable for sustainable forest management and the rational use of timber, as it enables the estimation of diameters along the bole and the determination of log assortments. This study aimed to compare the performance of different statistical and machine learning approaches for predicting the stem taper of *Tectona grandis* L.f. in Santarém, Pará, Brazil. A total of 30 trees were sampled, yielding 261 diameter observations (*di*) along the stem. Diameter at breast height (*dbh*), commercial height (*bc*), total height (*ht*), and relative height (*hi*) were used as predictor variables. The tested approaches included the Kozak taper model, Classification and Regression Tree (CART), Random Forest (RF), Support Vector Machine (SVM), and Gradient Boosting Machine (GBM). Model performance was evaluated using the root mean square error (RMSE), mean absolute error (MAE), and the linear correlation coefficient ($r_{\hat{y}y}$) for both training and generalization (testing) stages. The GBM algorithm achieved the best results, with $r_{\hat{y}y} > 0.99$ and an RMSE of 0.45 cm, followed closely by RF. The Kozak model and CART exhibited greater error dispersion and lower generalization ability. The relative error analysis indicated that GBM provided the most accurate predictions, with no evidence of systematic bias. We conclude that machine learning approaches, particularly GBM, are more effective for modeling teak stem taper, outperforming conventional regression models in predictive accuracy and precision.

Keywords: machine learning; artificial intelligence; forest mensuration.

1. INTRODUÇÃO

A implantação de reflorestamentos comerciais tem se consolidado como uma alternativa relevante para mitigar os impactos de atividades antrópicas associadas ao desmatamento do bioma amazônico, como o abandono de pastagens na pecuária extensiva, a mineração e outras formas

de uso predatório da terra (NUNES et al., 2020; VIEIRA; SILVA, 2024). Nesse contexto, destaca-se o cultivo da teca (*Tectona grandis* L.f.), presente tanto em extensas áreas de reflorestamento quanto em sistemas agroflorestais, atuando como espécie perene de grande importância econômica e ecológica (CARMONA et al., 2018; DOS SANTOS et al.,

2019). Considerando a relevância da teca no mercado madeireiro e no cenário dos reflorestamentos, torna-se imprescindível a quantificação acurada do volume de madeira produzido. Informações volumétricas confiáveis constituem subsídio fundamental para a tomada de decisão e para o uso racional dos recursos florestais (CAMPOS; LEITE, 2017). Essas estimativas podem ser obtidas por diferentes abordagens, incluindo o emprego de algoritmos de aprendizado de máquina, modelos de afilamento ou equações volumétricas tradicionais (SANTOS et al., 2023; TAVARES JÚNIOR et al., 2021).

O aprendizado de máquina (*machine learning*) é um subconjunto da inteligência artificial, voltado ao desenvolvimento de algoritmos e sistemas capazes de aprender com dados e aprimorar seu desempenho sem programação explícita. Enquanto a inteligência artificial busca construir sistemas computacionais capazes de desempenhar tarefas tipicamente associadas à cognição humana, o aprendizado de máquina concentra-se na criação de modelos que incorporam padrões e generalizações a partir da experiência (ZHOU, 2021). Na área da mensuração florestal, a aplicação de algoritmos de aprendizado de máquina tem se mostrado promissora, em virtude de sua capacidade de lidar com ruídos nos dados, de apresentar elevada capacidade de generalização e, muitas vezes, de superar modelos convencionais de regressão em termos de acurácia preditiva (CASAS et al., 2022; SILVA et al., 2023).

O afilamento do fuste, ou *taper*, refere-se ao perfil longitudinal da árvore, definido como a taxa de decréscimo do diâmetro ao longo do eixo principal (CAMPOS; LEITE, 2017). Funções de afilamento permitem estimar o diâmetro em diferentes alturas do fuste, possibilitando a determinação precisa de sortimentos e de multiprodutos de madeira (SALEKIN et al., 2021).

O estudo da forma do fuste tem sido amplamente conduzido em diversas espécies florestais, com aplicações práticas em manejo, inventário e indústria (LOPES et al., 2018; TAVARES JÚNIOR et al., 2021). Apesar do crescente interesse na temática, ainda são escassas as pesquisas que exploram o uso de algoritmos de aprendizado de máquina na predição do afilamento de espécies cultivadas em reflorestamentos amazônicos. Diante disso, o presente estudo tem como objetivo testar e avaliar o desempenho de diferentes abordagens na predição do afilamento do fuste de árvores de *Tectona grandis* L.f. no município de Santarém, Pará.

2. MATERIAL E MÉTODOS

2.1. Caracterização da área de estudo

O povoamento amostrado neste estudo está localizado na Fazenda Experimental da Universidade Federal do Oeste do Pará – UFOPA, situada às margens da rodovia PA-370, no município de Santarém, Pará. A classificação climática da região é Am equatorial úmido, segundo a classificação de Köppen, com uma estação seca bem definida e outra com índices pluviométricos elevados (ALVARES et al., 2013). A temperatura média anual varia de 25° a 28°C, com umidade relativa do ar média de 86% e precipitação pluvial média anual de até 1.920 mm (MARTORANO et al., 2021).

As árvores amostradas estão dispostas em um talhão de aproximadamente 0,1 hectares, com espaçamento de 3 x 2 m e 6 anos de idade. A área destinada ao reflorestamento foi utilizada anteriormente para atividades pecuárias. O preparo da área envolveu o corte e a queima da vegetação, além da

gradagem e da calagem. As mudas utilizadas foram produzidas a partir de sementes.

2.2. Coleta de dados

Foram amostradas 30 árvores de teca, escolhidas aleatoriamente no povoamento. Para cada indivíduo, foram obtidas as variáveis dendrométricas: diâmetro a 1,3 m de altura em cm (dap); altura comercial em m (hc) e altura total em m (ht), com hipômetro trigonométrico Vertex Haglöfs 5. O diâmetro (di) em qualquer altura (hi) foi obtido de forma não destrutiva, com o auxílio de uma escada. Foram estabelecidas alturas de 0,1; 0,5; 0,7; 1,0; 1,3 e, a partir de 2 m, de 1 em 1 m até atingir a altura comercial (ou di de 5 cm).

2.3. Abordagens para predição do afilamento

Para a predição dos diâmetros ao longo do fuste, foram utilizadas quatro abordagens baseadas em aprendizado de máquina e uma baseada em regressão linear. Foram totalizadas 261 observações de di, as quais foram divididas em dois conjuntos de dados: um para ajuste do modelo de regressão e treinamento dos algoritmos de aprendizado de máquina (70%, n = 184) e outro, independente, para generalização das abordagens (30%, n = 77).

Ajustou-se o modelo de Kozak na forma linear descrita na Equação 1. Para a estimativa dos parâmetros ajustados, adotou-se o método dos mínimos quadrados ordinários.

$$\hat{d}_i = \text{dap} \sqrt{\hat{\beta}_0 + \hat{\beta}_1 \left(\frac{h_i}{ht}\right) + \hat{\beta}_2 \left(\frac{h_i}{ht}\right)^2} + \varepsilon \quad (01)$$

em que: \hat{d}_i é o diâmetro a qualquer altura estimado pelo modelo em cm, dap é o diâmetro a 1,3 m de altura em cm, $\hat{\beta}_n$ são os parâmetros estimados da regressão, h_i é a altura da seção em m, ht é a altura total em m e ε é o erro aleatório sendo $\varepsilon \sim N(0, \sigma^2)$.

Quatro algoritmos de aprendizado de máquina foram testados para prever o di das árvores de teca: Random Forest (RF); Gradient Boosting (GBM); Árvore de Regressão (CART) e *Support Vector Machine* (SVM). As variáveis dap, hc, ht e hi foram utilizadas como preditoras em todos os algoritmos. As melhores combinações de hiperparâmetros para cada algoritmo utilizado estão na Tabela 1. Para o treinamento dos algoritmos adotou-se a validação cruzada com 10 folds e 30 repetições. A métrica de treinamento utilizada foi o erro médio absoluto (MAE).

Tabela 1. Combinações de hiperparâmetros para treinamento de algoritmos de aprendizado de máquina para prever o afilamento do fuste de árvores de teca (*Tectona grandis* L.f.) na Amazônia Oriental. Table 1. Hyperparameter combinations used for training machine learning algorithms to predict tree stem taper of teak (*Tectona grandis* L.f.) in the Eastern Amazon.

Algoritmo	Sigla	Combinação de hiperparâmetros
Random forest	RF	<i>mtry</i> = 4
Árvore de regressão	CART	<i>method</i> = "anova" <i>cp</i> = 0,1
Gradient boosting	GBM	<i>Shrinkage</i> = 0,1 <i>n.trees</i> = 500
Support Vector Machine - Radial	SVM	<i>Sigma</i> = 0,33 C = 1

Onde *mtry* é o número de variáveis amostradas aleatoriamente, *method* é o método de ajuste, *cp* é o controle de poda, *Shrinkage* é a taxa de aprendizado, *n.trees* é o número de árvores em sequência, *Sigma* da função de Kernel utilizada na máquina de suporte vetorial e C é a penalização da função de custo.

Para avaliação da precisão e da exatidão das predições do afilamento do fuste de teca por diferentes abordagens foram utilizadas as estatísticas de qualidade: raiz quadrada do erro quadrático médio em termos absolutos – RMSE (Eq. 2), erro médio absoluto – MAE (Eq. 3) e coeficiente de correlação linear entre d_i observado e d_i predito – $r_{\hat{y}y}$ (Eq. 4). As estatísticas foram obtidas para os conjuntos de treinamento e generalização. Foram construídos e interpretados gráficos conjuntos de d_i observados e d_i preditos, gráficos de erro relativo (Eq. 5) e histogramas de frequência de erro relativo.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (d_i - \hat{d}_i)^2}{n}} \quad (02)$$

$$MAE = \frac{\sum_{i=1}^n |d_i - \hat{d}_i|}{n} \quad (03)$$

$$r_{\hat{y}y} = \frac{(\sum_{i=1}^n (d_i - \bar{d})(\hat{d}_i - \bar{\hat{d}}))^2}{\sqrt{\sum_{i=1}^n (d_i - \bar{d})^2 \times \sum_{i=1}^n (\hat{d}_i - \bar{\hat{d}})^2}} \quad (04)$$

$$\text{Erro relativo (\%)} = \frac{(\hat{d}_i - d_i)}{d_i} \times 100 \quad (05)$$

em que: RMSE é a raiz quadrada do erro quadrático médio em cm, MAE é o erro médio absoluto, $r_{\hat{y}y}$ é o coeficiente de correlação linear entre diâmetro observado e diâmetro predito, d_i é o diâmetro observado na i -ésima altura (h_i), \hat{d}_i é o diâmetro predito na i -ésima altura (h_i), n é o número de observações, \bar{d} é a média do diâmetro observado, $\bar{\hat{d}}$ é a média do diâmetro predito.

3. RESULTADOS

O desempenho estatístico das cinco abordagens testadas na predição do afilamento do fuste de árvores de teca, nas etapas de treinamento e de generalização, é apresentado na Tabela 1. Todas as abordagens apresentaram desempenho estatisticamente ligeiramente inferior nas predições do conjunto de generalização. Os maiores RMSE (> 1 cm) e os menores $r_{\hat{y}y}$ (< 0,90) foram obtidos a partir das predições do algoritmo CART. O algoritmo GBM obteve os maiores $r_{\hat{y}y}$ (> 0,99) e menores MAE (< 0,33 cm) e RMSE (0,45 cm) em ambas as etapas da predição.

Tabela 2. Estatísticas de avaliação das abordagens preditivas testadas para prever o afilamento do fuste de árvores de teca na Amazônia Oriental.

Table 2. Evaluation statistics for the predictive approaches tested for stem taper prediction of teak trees in the Eastern Amazon.

Abordagem	Treinamento			Generalização		
	RMSE	MAE	$r_{\hat{y}y}$	RMSE	MAE	$r_{\hat{y}y}$
RF	0,3665	0,247	0,994	0,580	0,387	0,983
GBM	0,2643	0,184	0,996	0,448	0,329	0,989
CART	1,2441	0,947	0,911	1,348	1,027	0,899
SVM	0,7187	0,447	0,976	0,733	0,488	0,975
KOZAK	0,9712	0,738	0,949	0,889	0,703	0,963

A Figura 1 apresenta o perfil de afilamento do fuste de teca observado e predito por cada abordagem. Os algoritmos GBM e RF apresentaram predições com tendência à superestimação dos valores observados (Figura 2). O modelo

de Kozak e a árvore de regressão apresentaram maior dispersão dos erros, indicando variações mais acentuadas em relação aos diâmetros observados e um número maior de erros acima do valor de MAE. As predições obtidas com o GBM apresentaram menor dispersão em torno da reta de 45°, indicando maior exatidão entre os valores preditos e os observados.

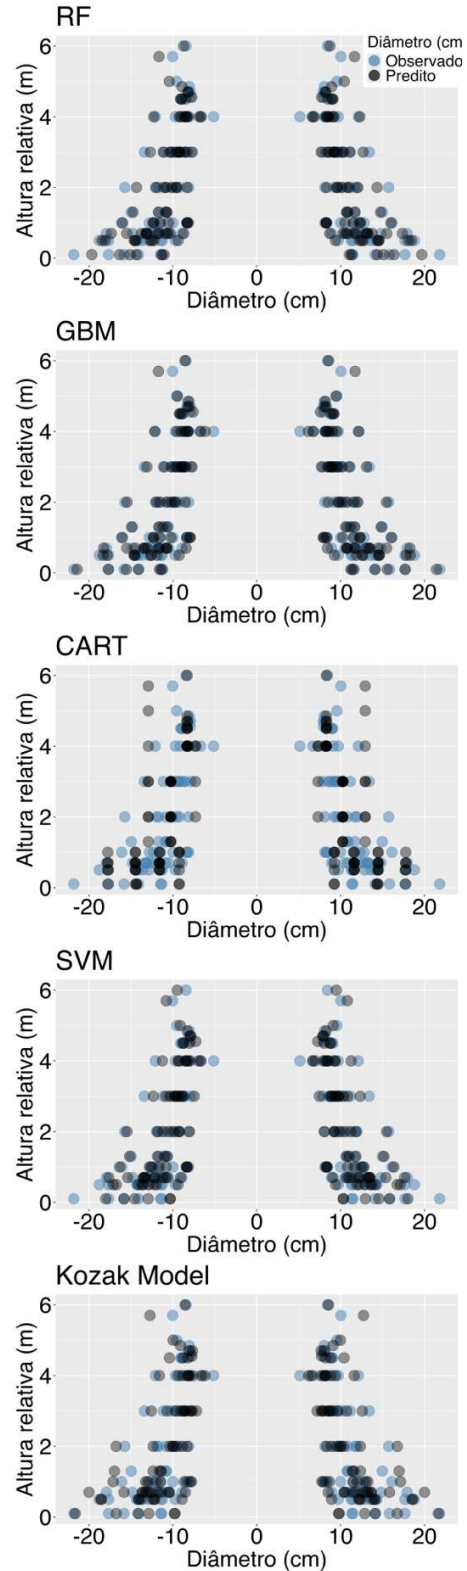


Figura 1. Perfil de afilamento do fuste de árvores de teca observado e predito por diferentes abordagens na Amazônia Oriental. Figure 1. Observed and predicted stem taper profile of teak trees using different approaches in the Eastern Amazon.

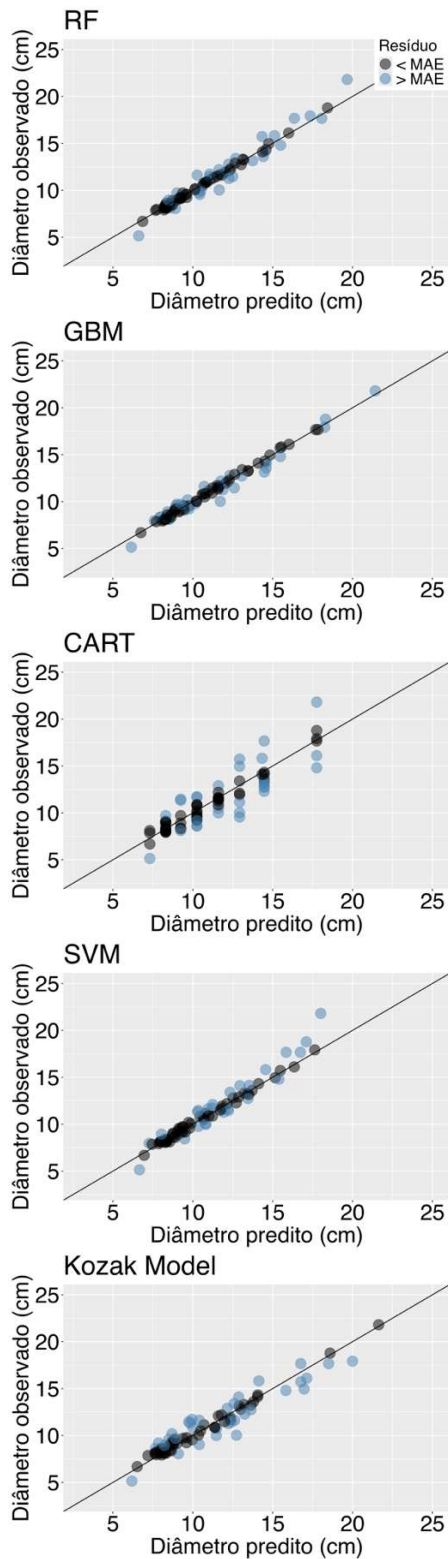


Figura 2. Dispersão entre os diâmetros observados e os preditos por diferentes abordagens em árvores de teca na Amazônia Oriental.
 Figure 2. Dispersion between observed and predicted diameters obtained using different approaches in teak trees in the Eastern Amazon.

A Figura 3 apresenta a análise dos erros relativos em função de di, bem como o histograma de frequência dos erros. As abordagens baseadas em regressão, CART e o modelo de Kozak apresentaram dispersão dos erros relativos, com distribuição mais ampla e amplitude mais elevada

(Figura 3). Além disso, observou-se a ocorrência de erros relativos superiores a $\pm 20\%$.

O algoritmo SVM demonstrou tendência à superestimação dos maiores diâmetros (superiores a 18 cm), tanto no treinamento quanto na generalização. Tendência semelhante, embora em menor magnitude, foi observada nas predições do algoritmo RF. Por sua vez, o algoritmo GBM apresentou erros concentrados nas classes próximas de zero, sem indícios de tendências sistemáticas nos erros relativos.

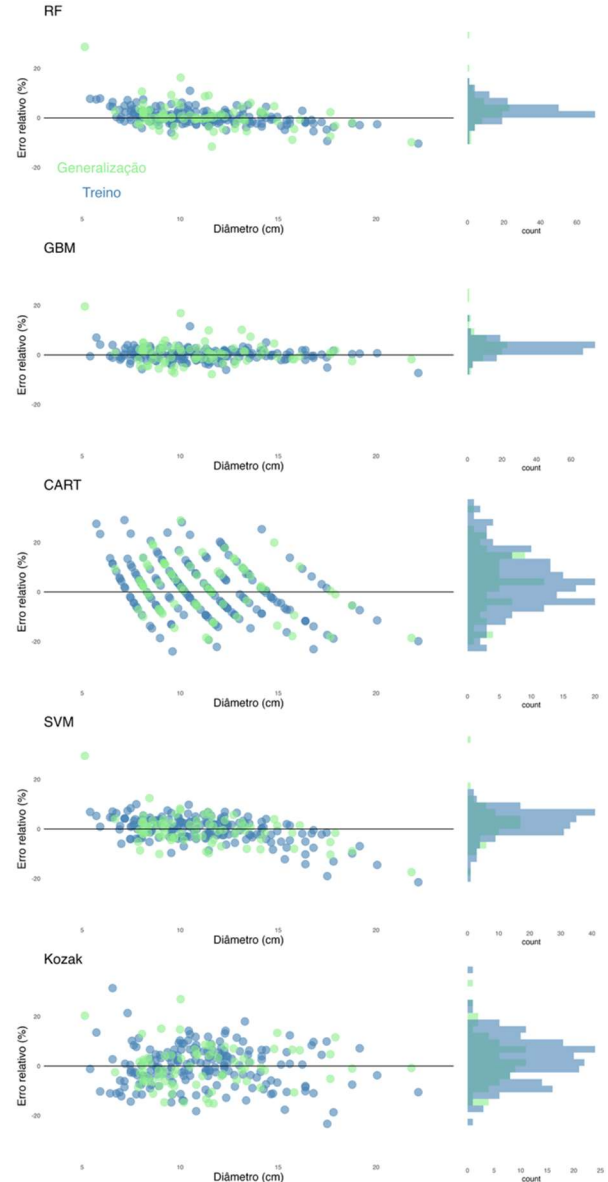


Figura 3. Erros relativos (%) entre os diâmetros observados e os preditos por diferentes abordagens em árvores de teca na Amazônia Oriental.

Figure 3. Relative errors (%) between observed and predicted diameters using different approaches in teak trees in Eastern Amazonia.

4. DISCUSSÃO

Os resultados obtidos neste estudo permitem avaliar, de forma comparativa, o desempenho de diferentes abordagens estatísticas e de aprendizado de máquina na predição do afilamento do fuste de árvores de *Tectona grandis* L.f. em Santarém, Pará.

As estatísticas de avaliação indicam um desempenho satisfatório das abordagens testadas na predição do

afilamento do fuste de árvores de teca. A redução de desempenho observada na etapa de generalização, em todas as abordagens, é um fenômeno esperado, uma vez que se trata de predição de dados independentes (CHEN et al., 2023; RYO, 2022; TAVARES JÚNIOR et al., 2021). No entanto, a magnitude das diferenças entre as duas etapas foi pouco acentuada, indicando ausência de sobreajuste.

O algoritmo GBM apresentou as estatísticas de avaliação mais adequadas entre as cinco abordagens testadas, com elevado $r_{\hat{y}y}$ e RMSE baixo. A eficiência dos algoritmos de aumento de gradiente se deve ao seu método de treinamento baseado em árvores de regressão ajustadas sequencialmente. Em cada iteração, uma nova árvore é construída para corrigir os erros residuais das iterações anteriores (SMITH; DOMKE; WOODALL, 2022; YANG et al., 2025). Tais características auxiliam na modelagem de fenômenos complexos não lineares, como o afilamento dos fustes.

A árvore de regressão demonstrou um desempenho geral com RMSE altos e $r_{\hat{y}y}$ inferiores a 0,90, indicando uma capacidade de generalização dos diâmetros de teca inferior às demais abordagens testadas. Os resultados do modelo de Kozak também foram inferiores em termos de desempenho estatístico, indicando menor capacidade preditiva em comparação à maioria das abordagens de aprendizado de máquina. Considerando que o modelo de Kozak e o CART são abordagens fundamentadas em regressão, espera-se que a inferioridade observada nas predições esteja associada à capacidade de captar relações não lineares e mais complexas entre as variáveis dendrométricas (RYO, 2022; SOUZA et al., 2018).

As análises gráficas das predições reforçam as tendências observadas nas avaliações estatísticas das abordagens. O algoritmo GBM demonstrou exatidão elevada na etapa de generalização, evidenciada por predições de diâmetro mais próximas à reta de 45°. Verificou-se uma tendência de subestimação de diâmetros maiores nas predições geradas pela SVM.

O desempenho dos algoritmos baseados em aprendizado estatístico, como SVM, está fortemente associado à função kernel utilizada (GÜNER; DIAMANTOPOULOU; ÖZÇELİK, 2023; VAPNIK, 2000). Dessa forma, o uso de outras funções poderia resultar em um melhor desempenho nas predições diamétricas para teca.

A análise gráfica dos erros relativos corrobora os resultados expostos anteriormente, indicando uma distribuição mais ampla nas abordagens CART e do modelo de Kozak, com erros superiores a $\pm 20\%$. Para o algoritmo GBM, a distribuição de erros relativos concentrou-se em torno de zero, sem indicativos de viés sistemático nas predições dos diâmetros de teca. Esse comportamento indica maior precisão e exatidão, atributos desejáveis em modelos preditivos de variáveis dendrométricas. Os resultados demonstraram a superioridade das abordagens baseadas em aprendizado de máquina, especialmente o algoritmo GBM, para a predição do afilamento do fuste de teca.

5. CONCLUSÕES

Os resultados desta pesquisa indicam que as abordagens testadas apresentaram desempenho satisfatório na predição do afilamento do fuste de *Tectona grandis* L.f. Entre os métodos avaliados, o algoritmo *Gradient Boosting Machine* (GBM) apresentou o melhor desempenho estatístico. Em contraste, as abordagens baseadas em regressão tradicional,

como o modelo de Kozak e a árvore de regressão (CART), demonstraram menor capacidade de representar a complexidade do afilamento do fuste.

Os achados reforçam o potencial do aprendizado de máquina, especialmente do GBM, como ferramenta eficaz para aprimorar a estimativa do afilamento em plantios de teca na Amazônia Oriental, proporcionando maior precisão no manejo florestal e no planejamento da produção.

6. REFERÊNCIAS

- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. de M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013. <https://doi.org/10.1127/0941-2948/2013/0507>
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração Florestal: perguntas e respostas**. 5. ed. Editora UFV, 2017. 636p.
- CARMONA, I. N.; AQUINO, M. G. C. de; ROCHA, D. Í. S. da; SILVA, J. J. das N.; FICAGNA, A. G.; BALONEQUE, D. D.; OTAKE, M. Y. F.; PAULETTO, D. Variáveis morfométricas de três espécies florestais em sistema agroflorestal. **Revista Agroecossistemas**, v. 10, n. 1, e131, 2018. <https://doi.org/10.18542/ragros.v10i1.5158>
- CASAS, G. G.; FARDIN, L. P.; SILVA, S.; OLIVEIRA NETO, R. R. de; BINOTI, D. H. B.; LEITE, R. V.; DOMICIANO, C. A. R.; LOPES, L. S. de S.; CRUZ, J. P. da; REIS, T. L. dos; LEITE, H. G. Improving yield projections from early ages in eucalypt plantations with the clutter model and artificial neural networks. **Pertanika Journal of Science and Technology**, v. 30, n. 2, p. 1257-1272, 2022. <https://doi.org/10.47836/pjst.30.2.22>
- CHEN, Z.; XIAO, F.; GUO, F.; YAN, J. Interpretable machine learning for building energy management: A state-of-the-art review. **Advances in Applied Energy**, v. 9, e100123, 2023. <https://doi.org/10.1016/j.adapen.2023.100123>
- DOS SANTOS, M. L.; RODRIGUES, R. P.; LIMA, M. D. R.; MARTINS, W. B. R.; COSTA, B. C.; SUZUKI, P. M. Hypsometric models for a clonal plantation of *Tectona grandis* Linn F. subjected to selective thinning. **Revista Agro@Mambiente On-Line**, v. 13, e35, 2019. <https://doi.org/10.18227/1982-8470ragro.v13i0.5292>
- GÜNER, Ş. T.; DIAMANTOPOULOU, M. J.; ÖZÇELİK, R. Diameter distributions in *Pinus sylvestris* L. stands: evaluating modelling approaches including a machine learning technique. **Journal of Forestry Research**, v. 34, n. 6, p. 1829-1842, 2023. <https://doi.org/10.1007/s11676-023-01625-2>
- LOPES, L. S. D. S.; RODE, R.; PAULETTO, D.; BALONEQUE, D. D.; SILVA, A. R.; SANTOS, K. N. F. dos. Ajuste dos modelos de taper e do sortimento de toras de mogno africano em sistemas agroflorestais em Belterra, Pará. **Revista Agroecossistemas**, v. 10, n. 1, e5213, 2018. <https://doi.org/10.18542/ragros.v10i1.5213>
- MARTORANO, L. G.; SOARES, W. B.; MORAES, J. R. da S. C. de; NASCIMENTO, W.; APARECIDO, L. E. de O.; VILLA, P. M. Climatology of air temperature in Belterra: thermal regulation ecosystem services provided by the Tapajós National Forest in the Amazon. **Revista**


- Brasileira de Meteorologia**, v. 36, n. 2, p. 327-337, 2021. <https://doi.org/10.1590/0102-77863620015>
- NUNES, S.; GASTAUER, M.; CAVALCANTE, R. B. L.; RAMOS, S. J.; CALDEIRA, C. F.; SILVA, D.; RODRIGUES, R. R.; SALOMÃO, R.; OLIVEIRA, M.; SOUZA-FILHO, P. W. M.; SIQUEIRA, J. O. Challenges and opportunities for large-scale reforestation in the Eastern Amazon using native species. **Forest Ecology and Management**, v. 466, e118120, 2020. <https://doi.org/10.1016/j.foreco.2020.118120>
- RYO, M. Explainable artificial intelligence and interpretable machine learning for agricultural data analysis. **Artificial Intelligence in Agriculture**, v. 6, p. 257-265, 2022. <https://doi.org/10.1016/j.aiaa.2022.11.003>
- SALEKIN, S.; CATALÁN, C. H.; BOCZNIEWICZ, D.; PHIRI, D.; MORGENROTH, J.; MEASON, D. F.; MASON, E. G. Global tree taper modelling: a review of applications, methods, functions, and their parameters. **Forests**, v. 12, n. 7, e913, 2021. <https://doi.org/10.3390/f12070913>
- SANTOS, M. L. dos; MIGUEL, E. P.; NAPPO, M. E.; SOUZA, H. J. de; SANTOS, C. R. C. dos; SILVA, J. N. M.; MATRICARDI, E. A. T. Approaches to Forest Site Classification as an Indicator of Teak Volume Production. **Forests**, v. 14, n. 8, e1613, 2023. <https://doi.org/10.3390/f14081613>
- SILVA, G. C. C.; NEVES, J. C. L.; MARCATTI, G. E.; SOARES, C. P. B.; CALEGARIO, N.; JÚNIOR, C. A. A.; GONZÁLES, D. G. E.; GLERIANI, J. M.; BINOTI, D. H. B.; PAIVA, H. N. de; LEITE, H. G. Improving 3-PG calibration and parameterization using artificial neural networks. **Ecological Modelling**, v. 479, e110301, 2023. <https://doi.org/10.1016/j.ecolmodel.2023.110301>
- SMITH, J. E.; DOMKE, G. M.; WOODALL, C. W. Predicting downed woody material carbon stocks in forests of the conterminous United States. **Science of the Total Environment**, v. 803, e150061, 2022. <https://doi.org/10.1016/j.scitotenv.2021.150061>
- SOUZA, G. S. A. de; COSENZA, D. N.; ARAÚJO, A. C. da S. C.; PIMENTA, L. V. A.; SOUZA, R. B.; ALMEIDA, F. M.; LEITE, H. G. Evaluation of non-linear taper equations for predicting the diameter of eucalyptus trees. **Revista Árvore**, v. 42, n. 1, e420102 2018. <https://doi.org/10.1590/1806-90882018000100002>
- TAVARES JÚNIOR, I. da S.; SOUZA, J. R. M. de; LOPES, L. S. de S.; FARDIN, L. P.; CASAS, G. G.; OLIVEIRA NETO, R. R. de; LEITE, R. V.; LEITE, H. G. Machine learning and regression models to predict multiple tree stem volumes for teak. **Southern Forests: a Journal of Forest Science**, v. 83, n. 4, p. 294-302, 2021. <https://doi.org/10.2989/20702620.2021.1994345>
- VAPNIK, V. N. **The Nature of Statistical Learning Theory**. New York, NY: Springer, 2000. 334p.
- VIEIRA, I. C. G.; SILVA, J. M. C. da. Zero deforestation and degradation in the Brazilian Amazon. **Trends in Ecology & Evolution**, v. 39, n. 5, p. 413-416, 2024. <https://doi.org/10.1016/j.tree.2024.03.004>
- YANG, S.-I.; BRANDEIS, T. J.; HELMER, E. H.; MARCANO-VEGA, H. Predicting species-specific diameter growth rate for Caribbean trees using mixed-effects extreme gradient boosting. **Forest Ecology and Management**, v. 580, e122520, 2025. <https://doi.org/10.1016/j.foreco.2025.122520>
- ZHOU, Z.-H. **Machine Learning**. Singapore: Springer Singapore, 2021. 460p.

Agradecimentos: À Universidade Federal Rural da Amazônia (UFRA) e à Universidade Federal do Oeste do Pará (UFOPA) pelo apoio em infraestrutura e recursos humanos. G.B-C. recebeu apoio do CNPq com uma Bolsa de Produtividade em Pesquisa (nº 304809/2025-0).

Contribuições dos autores: L.S.S.L., D.P., R.D., G.C.B., A.F.S.: metodologia, coleta de dados e redação (original); L.S.S.L., D.P., C.N.S., N.A.C.M.A., R.S.M.: conceitualização e redação (revisão e edição) e coleta de dados; L.S.S.L.: análise estatística; G.C.B.: obtenção de financiamento. Todos os autores leram e concordaram com a versão publicada do manuscrito.

Disponibilidade de dados: Os dados desta pesquisa poderão ser obtidos por e-mail, mediante solicitação ao autor correspondente ou ao segundo autor.

Conflito de interesses: Os autores declaram não haver conflitos de interesse.



Copyright: © 2026 by the authors. This article is an Open-Access article distributed under the terms and conditions of the Creative Commons **Attribution-NonCommercial (CC BY-NC)** license (<https://creativecommons.org/licenses/by/4.0/>).